

# 第十二讲 约束最小二乘和 $F$ 检验

2023.12.8

检验 $q$ 个回归系数为0


$$F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2} \stackrel{H_0}{\sim} F_{q,n-p}$$

# F分布

G.W. Snedecor (1881-1974), 美国统计学家, 1947年在Iowa State Univ创建了美国第一个统计系。Snedecor为了表示对Fisher的敬意, 称两个独立卡方随机变量的平均之比服从F分布, 也叫做Snedecor's F-分布:

$$F = \frac{U/d_1}{V/d_2} \sim F_{d_1, d_2}, \text{ 简记作 } \frac{\chi_{d_1}^2/d_1}{\chi_{d_2}^2/d_2} = F_{d_1, d_2}$$

其中  $U \sim \chi_{d_1}^2, V \sim \chi_{d_2}^2, U \perp V$ .



$$f(x) = \frac{\left(\frac{d_1}{d_2}\right)^{\frac{d_1}{2}}}{B\left(\frac{d_1}{2}, \frac{d_2}{2}\right)} x^{\frac{d_1}{2}-1} \left(1 + \frac{d_1}{d_2} x\right)^{-(d_1+d_2)/2}$$

注1: 若r.v.  $x \sim t_d$ , 则  $x^2 \sim F_{1,d}$ , 简记作  $(t_d)^2 = F_{1,d}$  或  $(t_d)^2 \sim F_{1,d}$ 。

注2:  $F = \frac{U/d_1}{V/d_2} \sim F_{d_1, d_2}$ , 若  $d_2 \rightarrow \infty$ , 则由大数律,  $V/d_2 \rightarrow 1$ , 因此

$$F \approx \frac{U}{d_1} \sim \chi_{d_1}^2/d_1,$$

若  $d_1$  也较大, 则近似地  $F \sim N(1, 2/d_1)$ 。

注3: 若  $F = \frac{U/d_1}{V/d_2} \sim F_{d_1, d_2}$  ( $U \sim \chi_{d_1}^2, V \sim \chi_{d_2}^2, U \perp V$ ), 则

$$\frac{d_1 F}{d_1 F + d_2} = \frac{U}{U + V} \sim \text{Beta}\left(\frac{d_1}{2}, \frac{d_2}{2}\right)$$

简记作  $\frac{\chi_{d_1}^2}{\chi_{d_1}^2 + \chi_{d_2}^2} \sim \text{Beta}\left(\frac{d_1}{2}, \frac{d_2}{2}\right)$

引理1. 假设  $\mathbf{x} \sim N_n(0, I_n)$ , 假设  $B$  是投影矩阵, 则

(1)  $\mathbf{x}^\top B\mathbf{x} = \|B\mathbf{x}\|^2 \sim \chi_r^2, r = \text{rank}(B)$

(2) 若  $AB = 0$ , 则  $A\mathbf{x}$  与  $B\mathbf{x}$  独立, 特别地,  $A\mathbf{x}$  与  $\mathbf{x}^\top B\mathbf{x}$  独立。

$B\mathbf{x}$  的分布?

$B\mathbf{x} \sim N_n(0, B)$

退化多元正态分布

证明: 假设  $B$  的谱分解为  $B = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top$ , 令  $\mathbf{y} = O^\top \mathbf{x} = \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} \sim N(0, I_p)$ ,

(1)  $\mathbf{x}^\top B\mathbf{x} = \mathbf{x}^\top O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top \mathbf{x} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top) \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} = \mathbf{y}_1^\top \mathbf{y}_1 \sim \chi_r^2.$

(2)  $B\mathbf{x} = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top \mathbf{x} = O \begin{pmatrix} \mathbf{y}_1 \\ 0 \end{pmatrix} = O_1 \mathbf{y}_1$ , 其中  $O_1$  为  $O = (O_1, O_2)$  的前  $r$  列。


由  $AB = 0 \Rightarrow AO \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top = 0$ , 划分  $AO = (C, D) \Rightarrow (C, D) \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} = 0 \Rightarrow C = 0$ ,

则  $A\mathbf{x} = AO\mathbf{y} = (C, D) \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} = D\mathbf{y}_2$ , 与  $B\mathbf{x} = O_1 \mathbf{y}_1$  独立。

命题1. 假设  $P = P_V$  是一个(子空间  $V$  的)  $n \times n$  投影矩阵,  
 $r = \text{rank}(P) = \dim(V)$ , 若  $\mathbf{x} \sim N_n(0, I_n)$ , 则

$$\frac{\|P\mathbf{x}\|^2/r}{\|(I_n - P)\mathbf{x}\|^2/(n-r)} \sim \frac{\chi_r^2/r}{\chi_{n-r}^2/(n-r)} \sim F_{r, n-r}$$

证:  $\|P\mathbf{x}\|^2 \sim \chi_r^2$ ,  $\|(I_n - P)\mathbf{x}\|^2 \sim \chi_{n-r}^2$ , 且与  $\|P\mathbf{x}\|^2$  独立。



$$\begin{aligned} \mathbf{x} &= P\mathbf{x} + (I_n - P)\mathbf{x} \\ \|\mathbf{x}\|^2 &= \|P\mathbf{x}\|^2 + \|(I_n - P)\mathbf{x}\|^2 \\ \chi_n^2 &= \chi_r^2 + \chi_{n-r}^2 \end{aligned}$$

$$\begin{aligned} \text{ctg}^2(\theta) &= \frac{\|P\mathbf{x}\|^2}{\|(I_n - P)\mathbf{x}\|^2} \sim \frac{r}{n-r} F_{r, n-r} \\ \cos^2(\theta) &= \frac{\|P\mathbf{x}\|^2}{\|\mathbf{x}\|^2} \sim \text{Beta}\left(\frac{r}{2}, \frac{n-r}{2}\right) \end{aligned}$$

当初定义F分布的时候, 如果卡方不除以自由度, 应用起来就会更方便一些。

# 一般线性假设的F检验

科学是一种系统性的知识体系，它积累并组织可检验的有关于万物的解释或理论。科学强调理论的可证伪性。科学不是寻求绝对的真理，而是在现有基础上，摸索式地不断接近真理。假设检验是对科学假设进行判断的工具。

Wald检验是最直观的检验。非正态总体假设下，其原假设下的渐近分布为卡方分布（我们直接使用该结论）。

## 一般的 Wald 检验

假设 $\theta$ 是参数向量， $\hat{\theta}$ 是 $\theta$ 的一个估计(例如MLE、LS)，考虑零假设  
 $H_0: \varphi(\theta) = \mathbf{c}_0$  ( $\mathbf{c}_0$ 是已知的 $q \times 1$ 向量)，定义Wald统计量

$$W = (\varphi(\hat{\theta}) - \mathbf{c}_0)^\top \hat{\Sigma}^{-1} (\varphi(\hat{\theta}) - \mathbf{c}_0),$$

其中 $\Sigma = \text{var}(\varphi(\hat{\theta}))$ ， $\hat{\Sigma} = \text{var}(\varphi(\hat{\theta}))$ 为 $\Sigma$ 的估计。

$H_0$ 成立时， $W \xrightarrow{d} \chi_q^2, n \rightarrow \infty$ 。

当 $\theta$ 是标量时， $H_0: \theta = \theta_0$ ，Wald检验统计量

$$Z = (\hat{\theta} - \theta_0) / \text{sd}(\hat{\theta}), \text{ 或 } W = Z^2,$$

$H_0$ 成立时， $W \xrightarrow{d} \chi_1^2$ 或 $Z \xrightarrow{d} N(0,1)$ 。

## 一般线性假设

假设正态线性回归模型： $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}_{n \times 1}$ ， $\boldsymbol{\varepsilon} \sim N_n(0, \sigma^2 I_n)$

$H_0: A\boldsymbol{\beta} = \mathbf{c}_0$  称为一般线性假设，其中  $A, \mathbf{c}_0$  已知， $A$  行满秩。

有关  $\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_{p-1})^\top$  的检验问题一般都可写成上述线性假设的形式，如  $p = 3$  时， $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2)^\top$

$$H_0: \beta_1 = 0 \Leftrightarrow H_0: \mathbf{a}^\top \boldsymbol{\beta} = 0, \mathbf{a} = (0, 1, 0)^\top$$

$$H_0: \beta_1 = \beta_2 = 0 \Leftrightarrow H_0: A\boldsymbol{\beta} = 0, A = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

$A$  的选取方式不唯一，例如上述第二个例子中也可取  $A = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 1 & -1 \end{pmatrix}$ 。

但后续一般线性假设的  $F$  检验是唯一的（不依赖于  $A$  的选取方式）。

## Wald 检验

对于一般线性假设  $H_0: A_{q \times p} \boldsymbol{\beta} = \mathbf{c}_0$ ,  $\boldsymbol{\theta} = A\boldsymbol{\beta}$  的LS估计为  $\hat{\boldsymbol{\theta}} = A\hat{\boldsymbol{\beta}}$ ,  $\Sigma = \text{var}(\hat{\boldsymbol{\theta}} | X) = \sigma^2 A(X^\top X)^{-1} A^\top$ , 其估计  $\hat{\Sigma} = \hat{\sigma}^2 A(X^\top X)^{-1} A^\top$ .  $H_0$  的Wald检验(不假设误差正态):

$$W = (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0)^\top \left( \hat{\sigma}^2 A(X^\top X)^{-1} A^\top \right)^{-1} (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0) \stackrel{H_0 \text{下近似}}{\sim} \chi_q^2.$$

但线性模型的统计推断通常假设误差正态, 此时  $W$  或  $F = W/q$  具有精确分布 ( $F$ 分布)。后续我们将假设误差正态。

## F检验

当误差服从正态分布时,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ , 定义  $F$  检验统计量

$$F = W / q,$$

我们将证明  $F \stackrel{H_0}{\sim} F_{q, n-p}$ , 或等价地  $W \stackrel{H_0}{\sim} qF_{q, n-p}$ .



定理1. 假设模型  $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}_{n \times 1}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ ,  $X$ 列满秩, 则

- (1)  $\hat{\boldsymbol{\beta}} | X \sim N(\boldsymbol{\beta}, \sigma^2 (X^T X)^{-1})$ ,
- (2)  $\frac{(n-p)\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-p}^2$ , 且  $\hat{\boldsymbol{\beta}}, \hat{\sigma}^2$  独立。

证明:

(1) 由  $\mathbf{y} | X \sim N(X\boldsymbol{\beta}, \sigma^2 I_n)$  知  $\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y} \sim N(\boldsymbol{\beta}, \sigma^2 (X^T X)^{-1})$ 。

(2) 因为  $\mathbf{e} = (I_n - P_X) \mathbf{y} = (I_n - P_X)(X\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = (I_n - P_X)\boldsymbol{\varepsilon}$ ,

所以  $(n-p)\hat{\sigma}^2/\sigma^2 = \|\mathbf{e}\|^2/\sigma^2 = \mathbf{z}^T (I_n - P_X) \mathbf{z}$ , 其中  $\mathbf{z} = \boldsymbol{\varepsilon}/\sigma \sim N(0, I_n)$ ,

$\text{rank}(I_n - P_X) = \text{tr}(I_n - P_X) = n - p$ , 所以  $(n-p)\hat{\sigma}^2/\sigma^2 \sim \chi_{n-p}^2$ 。

另外,  $\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y} = (X^T X)^{-1} X^T (X\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = \boldsymbol{\beta} + (X^T X)^{-1} X^T \boldsymbol{\varepsilon} \triangleq \boldsymbol{\beta} + B\boldsymbol{\varepsilon}$

$\mathbf{e} = (I_n - P_X)\boldsymbol{\varepsilon}$ , 由  $B(I_n - P_X) = 0$ , 知  $\hat{\boldsymbol{\beta}}$  与  $\hat{\sigma}^2$  独立。

$\mathbf{x} \sim N(0, \sigma^2 I_n)$ , 若  $AB^T = 0$ , 则  $A\mathbf{x}, B\mathbf{x}$  独立。

定理2. 线性模型  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 \mathbf{I}_n)$ , 假设  $\mathbf{A}_{q \times p}$  是已知的行满秩矩阵

$$\text{则 } F = \frac{(\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}_0)^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}_0)}{q\hat{\sigma}^2} \stackrel{H_0}{\sim} F_{q, n-p}^\circ$$

证明:  $\hat{\boldsymbol{\beta}} | \mathbf{X} \sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1}) \Rightarrow \mathbf{A}\hat{\boldsymbol{\beta}} \sim N(\mathbf{A}\boldsymbol{\beta} - \mathbf{c}_0, \sigma^2 \mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)$ ,

故  $H_0$  成立时,  $\mathbf{z} \stackrel{\Delta}{=} (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1/2} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta}) / \sigma \sim N(0, \mathbf{I}_q)$ , 从而

$$a \stackrel{\Delta}{=} \|\mathbf{z}\|^2 = \frac{1}{\sigma^2} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta})^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta}) \sim \chi_q^2,$$

由定理1,  $b \stackrel{\Delta}{=} \frac{1}{\sigma^2} (n-p)\hat{\sigma}^2 \sim \chi_{n-p}^2$ , 且  $\hat{\sigma}^2$  与  $\hat{\boldsymbol{\beta}}$  独立,  $\Rightarrow a, b$  独立, 故  $H_0$  成立时

$$\frac{a/q}{b/(n-p)} = \frac{(\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta})^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta})}{q\hat{\sigma}^2} \sim F_{q, n-p}$$

推论: 考虑一般线性假设  $H_0: \mathbf{A}\boldsymbol{\beta} = \mathbf{c}_0$ , 其中  $\mathbf{A}_{q \times p}, \mathbf{c}_0_{q \times 1}$  已知, 则  $H_0$  成立时,

$$F = (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}_0)^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{c}_0) / q\hat{\sigma}^2 \sim F_{q, n-p}^\circ$$

# 约束最小二乘

下面从投影角度考察一般线性假设的 $F$ 检验。

首先考虑零假设 $H_0: A\boldsymbol{\beta} = \mathbf{c}_0$ 成立时 $\boldsymbol{\beta}$ 的约束最小二乘估计。

我们不妨假设 $\mathbf{c}_0 = \mathbf{0}$ ，这是因为：

$A\boldsymbol{\beta} = \mathbf{c}_0 \Leftrightarrow A\boldsymbol{\beta}^* = \mathbf{0}$ ，其中 $\boldsymbol{\beta}^* = \boldsymbol{\beta} - A^\top(AA^\top)^{-1}\mathbf{c}_0$ ，此时模型

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = X(\boldsymbol{\beta}^* + A^\top(AA^\top)^{-1}\mathbf{c}_0) + \boldsymbol{\varepsilon} = X\boldsymbol{\beta}^* + XA^\top(AA^\top)^{-1}\mathbf{c}_0 + \boldsymbol{\varepsilon}$$

记 $\mathbf{y}^* = \mathbf{y} - XA^\top(AA^\top)^{-1}\mathbf{c}_0$ （注意 $XA^\top(AA^\top)^{-1}\mathbf{c}_0$ 已知），则

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad H_0: A\boldsymbol{\beta} = \mathbf{c}_0 \Leftrightarrow \mathbf{y}^* = X\boldsymbol{\beta}^* + \boldsymbol{\varepsilon}, \quad H_0: A\boldsymbol{\beta}^* = \mathbf{0}$$

约束最小  
二乘问题

假设线性模型 $\mathbf{y} = X_{n \times p}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ ， $\boldsymbol{\varepsilon} \sim (0, \sigma^2 I_n)$ ，设 $A_{q \times p}$ 为行满秩常数矩阵，  
线性约束下的最小二乘问题

$$\min_{\boldsymbol{\beta} \in R^p} \|\mathbf{y} - X\boldsymbol{\beta}\|^2 \quad s.t. \quad A\boldsymbol{\beta} = \mathbf{0} \quad (*)$$

命题2.假设 $X$ 列满秩, 约束最小二乘问题 (\*) 的最优解, 即约束最小二乘估计为

$$\tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} - (X^T X)^{-1} A^T \left( A (X^T X)^{-1} A^T \right)^{-1} A \hat{\boldsymbol{\beta}}.$$

证明1: 应用拉格朗日乘子法, 令

$$f(\boldsymbol{\beta}, \boldsymbol{\lambda}) = \|\mathbf{y} - X\boldsymbol{\beta}\|^2 + 2\boldsymbol{\lambda}^T (A\boldsymbol{\beta} - \mathbf{c}_0)$$

对 $\boldsymbol{\beta}$ 求偏导并令之为0得:  $X^T X\boldsymbol{\beta} - X^T \mathbf{y} + A^T \boldsymbol{\lambda} = 0$

$$\Rightarrow \tilde{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y} - (X^T X)^{-1} A^T \boldsymbol{\lambda} = \hat{\boldsymbol{\beta}} - (X^T X)^{-1} A^T \boldsymbol{\lambda}$$

$$\text{代入 } 0 = A\tilde{\boldsymbol{\beta}} = A\hat{\boldsymbol{\beta}} - A(X^T X)^{-1} A^T \boldsymbol{\lambda} \Rightarrow \boldsymbol{\lambda} = \left( A(X^T X)^{-1} A^T \right)^{-1} A \hat{\boldsymbol{\beta}},$$

$$\tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} - (X^T X)^{-1} A^T \left( A(X^T X)^{-1} A^T \right)^{-1} A \hat{\boldsymbol{\beta}}.$$

注: 由命题1, 在线性约束下, 拟合值

$$\hat{\mathbf{y}}_0 = X\tilde{\boldsymbol{\beta}} = \hat{\mathbf{y}} - X(X^T X)^{-1} A^T \left( A(X^T X)^{-1} A^T \right)^{-1} A \hat{\boldsymbol{\beta}}$$

这应该是 $\mathbf{y}$ 在约束下的自变量空间 $V_0$ 的投影,  $V_0 = ?$

命题3. 约束 $A_{q \times p} \boldsymbol{\beta} = \mathbf{0}$ 成立时,  $X$ 张成的空间 (称为自变量空间)

$$V_0 \stackrel{\Delta}{=} \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}, \boldsymbol{\beta} \in R^p\} = C(X(X^T X)^{-1} A^T)^\perp \cap C(X)$$

且该空间的投影阵 $P_{V_0} = P_X - P_{X(X^T X)^{-1} A^T}$

证明: 若 $\boldsymbol{\mu} \in V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}, \boldsymbol{\beta} \in R^p\} \subset C(X)$ ,

即存在 $\boldsymbol{\beta} \in R^p$ 使得 $\boldsymbol{\mu} = X\boldsymbol{\beta} \Rightarrow \boldsymbol{\beta} = (X^T X)^{-1} X^T \boldsymbol{\mu}$ ,

$\mathbf{0} = A\boldsymbol{\beta} = A(X^T X)^{-1} X^T \boldsymbol{\mu} \Rightarrow \boldsymbol{\mu} \in C(X(X^T X)^{-1} A^T)^\perp$ , 但 $\boldsymbol{\mu} \in C(X)$ ,

所以 $\boldsymbol{\mu} \in C(X) \cap C(X(X^T X)^{-1} A^T)^\perp$ , 所以

$$V_0 \subset C(X) \cap C(X(X^T X)^{-1} A^T)^\perp.$$

反之也对, 所以 $V_0 = C(X) \cap C(X(X^T X)^{-1} A^T)^\perp$ ,

即 $C(X(X^T X)^{-1} A^T) \oplus V_0 = C(X)$ , 所以 $P_X = P_{X(X^T X)^{-1} A^T} + P_{V_0}$ .

注:  $\mathbf{y}$ 在 $V_0$ 上的投影 $\hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y}$ 使得约束最小二乘(\*)达到最小,

$$\begin{aligned} \hat{\mathbf{y}}_0 &= P_{V_0} \mathbf{y} = P_V \mathbf{y} - P_{X(X^T X)^{-1} A^T} \mathbf{y} = X\hat{\boldsymbol{\beta}} - X(X^T X)^{-1} A^T (A(X^T X)^{-1} A^T)^{-1} A\hat{\boldsymbol{\beta}} \\ &= X[\hat{\boldsymbol{\beta}} - (X^T X)^{-1} A^T (A(X^T X)^{-1} A^T)^{-1} A\hat{\boldsymbol{\beta}}] = X[\tilde{\boldsymbol{\beta}}] \end{aligned}$$

由此我们用投影方法求出了 $\boldsymbol{\beta}$ 的约束LS估计 $\tilde{\boldsymbol{\beta}}$ .

需要说明的是，理论上我们需要命题2的约束最小二乘估计的数学公式，但在具体的线性假设检验问题中可以将约束代入模型进行简化。

例1. 假设模型

$$\mathbf{y} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \cdots + \mathbf{x}_{p-1}\beta_{p-1} + \boldsymbol{\varepsilon}$$

设计阵  $X = C(\mathbf{1}, \mathbf{x}_1, \dots, \mathbf{x}_{p-1})$  是  $n \times p$  矩阵, 约束:  $\beta_1 = \cdots = \beta_{p-1}$

将约束代入模型得

$$\mathbf{y} = \mathbf{1}\beta_0 + (\mathbf{x}_1 + \cdots + \mathbf{x}_{p-1})\beta_1 + \boldsymbol{\varepsilon},$$

设计阵  $X_0 = C(\mathbf{1}, \mathbf{x}_1 + \cdots + \mathbf{x}_{p-1})$  是  $n \times 2$  矩阵, 这是简单线性模型, 由此解得  $\beta_1$  的LS估计  $\hat{\beta}_1$ ,

$\Rightarrow \beta_1, \dots, \beta_{p-1}$  的约束LS估计都是  $\hat{\beta}_1$ 。

# F检验的其它表示

记权模型下和零模型（null model, 零假设下的模型）下的投影分别为

$$\hat{\mathbf{y}} = P_V \mathbf{y} = X\hat{\boldsymbol{\beta}}, \quad \hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y} = X\tilde{\boldsymbol{\beta}}$$

其中  $V = C(X)$ ,  $V_0 = \{X\boldsymbol{\beta} | A\boldsymbol{\beta} = \mathbf{0}\}$ , 则由命题2知

$$\hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = X(X^\top X)^{-1} A^\top [A(X^\top X)^{-1} A^\top]^{-1} A\hat{\boldsymbol{\beta}},$$

$$\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \hat{\boldsymbol{\beta}}^\top A^\top [A(X^\top X)^{-1} A^\top]^{-1} A\hat{\boldsymbol{\beta}}$$

代表全模型和零模型的拟合值差别, , 是F检验的关键部分。由定理2,

$$F = \hat{\boldsymbol{\beta}}^\top A^\top [A(X^\top X)^{-1} A^\top]^{-1} A\hat{\boldsymbol{\beta}} / q \hat{\sigma}^2 = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}$$

进一步, 根据几何和统计意义我们还可得到F统计量的其它表示。例如


$$\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 - \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = RSS_0 - RSS$$

度量了全模型和零模型的残差平方和的差别

$$\Rightarrow F = \frac{n-p}{q} \times \frac{RSS_0 - RSS}{RSS}$$

对比全模型  
和零模型

	自变量空间	投影	残差平方和	决定系数
全模型 $\beta \in R^p$	$V = \{X\beta   \beta \in R^p\}$ $\dim(V) = p$	$\hat{y} = P_V y$	$RSS = \ y - \hat{y}\ ^2$	$R^2 = \frac{\ \hat{y} - 1\bar{y}\ ^2}{\ y - 1\bar{y}\ ^2}$
零模型 $A\beta = 0$	$V_0 = \{X\beta   A\beta = 0\}$ $\dim(V_0) = p - q$	$\hat{y}_0 = P_{V_0} y$	$RSS_0 = \ y - \hat{y}_0\ ^2$	$R_0^2 = \frac{\ \hat{y}_0 - 1\bar{y}\ ^2}{\ y - 1\bar{y}\ ^2}$



$$\begin{aligned}
 y - \hat{y}_0 &= \hat{y} - \hat{y}_0 + y - \hat{y} \\
 \|y - \hat{y}_0\|^2 &= \|\hat{y} - \hat{y}_0\|^2 + \|y - \hat{y}\|^2 \\
 \chi_{n-\dim(V_0)}^2 &= \chi_{\dim(V)-\dim(V_0)}^2 + \chi_{n-\dim(V)}^2
 \end{aligned}$$

$\|\hat{y} - \hat{y}_0\|^2$ : 全模型和零模型的差别

$$\begin{aligned}
 F &= \frac{\|\hat{y} - \hat{y}_0\|^2/q}{\|y - \hat{y}\|^2/(n-p)} = \frac{(RSS_0 - RSS)/q}{RSS/(n-p)} \\
 R_p^2 &= \cos^2(\theta) = \frac{\|\hat{y} - \hat{y}_0\|^2}{\|y - \hat{y}_0\|^2} = \frac{RSS_0 - RSS}{RSS_0} = \frac{R^2 - R_0^2}{1 - R_0^2} \\
 F &= \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R_0^2} = \frac{n-p}{q} \times \frac{R_p^2}{1 - R_0^2}
 \end{aligned}$$

细节参  
见命题4



命题4. 线性模型  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ ,  $H_0: \mathbf{A}\boldsymbol{\beta} = \mathbf{0}$  的  $F$  检验

$$(1) F = \frac{(\mathbf{A}\hat{\boldsymbol{\beta}})^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}})}{q\hat{\sigma}^2} = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2} \sim F_{q, n-p}$$

$$(2) F \text{ 有如下等价表示: } F = \frac{n-p}{q} \times \frac{(RSS_0 - RSS)}{RSS}$$

$$(3) \text{ 若 } \mathbf{A} = (\mathbf{0}, *) \text{, 即 } \mathbf{A} \text{ 的第一列为 } \mathbf{0} \text{, 则 } F = \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R^2} = \frac{n-p}{q} \times \frac{R_p^2}{1 - R_p^2},$$

$$\text{其中 } R_p^2 = \frac{R^2 - R_0^2}{1 - R_0^2} = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2}.$$

前两页已基本证明, 可忽略

证明: (1) 零假设成立时,  $\boldsymbol{\beta}$  满足约束  $\mathbf{A}\boldsymbol{\beta} = \mathbf{0}$ , 由命题3,

$$\hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y} = P_V \mathbf{y} - P_{\mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top} \mathbf{y} = \hat{\mathbf{y}} - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} \mathbf{A}\hat{\boldsymbol{\beta}}$$

$$\Rightarrow \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \hat{\boldsymbol{\beta}}^\top \mathbf{A}^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} \mathbf{A}\hat{\boldsymbol{\beta}}, \text{ 而 } \hat{\sigma}^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n-p),$$

$$\Rightarrow F = \frac{\hat{\boldsymbol{\beta}}^\top \mathbf{A}^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} \mathbf{A}\hat{\boldsymbol{\beta}}}{q\hat{\sigma}^2} = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}.$$

下面利用投影表示证明  $F \stackrel{H_0}{\sim} F_{q, n-p}$  (比定理2的证明更直观一些):

$H_0$  下  $A\boldsymbol{\beta} = \mathbf{0}$ , 故  $P_{X(X^\top X)^{-1}A^\top} X\boldsymbol{\beta} = (\cdots)A\boldsymbol{\beta} = \mathbf{0}$ ,

所以  $\hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = (P_V - P_{V_0})\mathbf{y} = P_{X(X^\top X)^{-1}A^\top} (X\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = P_{X(X^\top X)^{-1}A^\top} \boldsymbol{\varepsilon}$ ,

由推论1,  $a \stackrel{\Delta}{=} \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 \sim \sigma^2 \chi_q^2$ , 其中  $\text{rank}(X(X^\top X)^{-1}A^\top) = \text{rank}(A) = q$ .

另一方面  $\mathbf{y} - \hat{\mathbf{y}} = (I - P_V)(X\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = (I - P_V)\boldsymbol{\varepsilon} \Rightarrow b \stackrel{\Delta}{=} \|\mathbf{y} - \hat{\mathbf{y}}\|^2 \sim \sigma^2 \chi_{n-p}^2$

因为  $(I - P_V)P_{X(X^\top X)^{-1}A^\top} = \mathbf{0}$ ,  $a, b$  独立, 所以  $H_0$  下  $F = \frac{a/q}{b/(n-p)} \sim F_{q, n-p}$ .

(2) 因为  $\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 - \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = RSS_0 - RSS \Rightarrow F = \frac{(RSS_0 - RSS)/q}{RSS/(n-p)}$

(3) 记  $A = (\mathbf{0}, B)$ , 则  $A\boldsymbol{\beta} = (\mathbf{0}, B) \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix} = B\mathbf{b}$  (从而约束  $A\boldsymbol{\beta} = \mathbf{0}$  对  $\beta_0$  没有约束),

而  $X\boldsymbol{\beta} = (\mathbf{1}, Z) \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix} = \mathbf{1}\beta_0 + Z\mathbf{b} \Rightarrow V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}, \boldsymbol{\beta} \in R^p\} = \{\mathbf{1}\beta_0 + Z\mathbf{b} : B\mathbf{b} = \mathbf{0}, \mathbf{b} \in R^{p-1}\}$ ,

$$\mathbf{1} \in V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = 0, \boldsymbol{\beta} \in R^p\} = \{\mathbf{1}\beta_0 + Z\mathbf{b} : B\mathbf{b} = 0, \mathbf{b} \in R^{p-1}\},$$

所以  $\mathbf{1} \perp \hat{\mathbf{y}} - \hat{\mathbf{y}}_0$ ,  $\mathbf{1}^\top \hat{\mathbf{y}}_0 = \mathbf{1}^\top \hat{\mathbf{y}} = \mathbf{1}^\top \mathbf{y} = n\bar{y}$

$$R^2 = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}, R_0^2 = \frac{\|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}, \|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2 + \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2$$

$$R^2 - R_0^2 = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}$$

而  $1 - R^2 = 1 - \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = \frac{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}$ , 所以

$$\frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2} = \frac{R^2 - R_0^2}{1 - R^2} \Rightarrow F = \frac{n - p}{q} \times \frac{R^2 - R_0^2}{1 - R^2}.$$

若记  $R_p^2 = \frac{R^2 - R_0^2}{1 - R_0^2}$ , 则  $F = \frac{n - p}{q} \times \frac{R_p^2}{1 - R_p^2}$ . 证毕

# 部分回归系数的F检验

模型:  $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon} = \mathbf{1} \beta_0 + X_1 \boldsymbol{\beta}_1 + X_2 \boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ ,  $V = C(\mathbf{1}, X_1, X_2)$

原假设  $H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$ , 记  $H_0$  成立时的子模型为  $\mathbf{y} = \mathbf{1} \beta_0 + X_1 \boldsymbol{\beta}_1 + \boldsymbol{\varepsilon}$ ,  $V_0 = C(\mathbf{1}, X_1)$ 。

命题5. 假设模型  $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon} = \mathbf{1} \beta_0 + X_1 \boldsymbol{\beta}_1 + X_2 \boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$ ,  $H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$ , 记  $X_2^\perp = X_2 - P_{V_0} X_2 = X_2 - P_{\mathbf{1}, X_1} X_2$ , 则  $H_0$  的F检验统计量为

$$F = \frac{\|X_2^\perp \hat{\boldsymbol{\beta}}_2\|^2}{q \hat{\sigma}^2} \stackrel{H_0}{\sim} F_{q, n-p},$$

其中  $\hat{\boldsymbol{\beta}}_2 = (X_2^{\perp \top} X_2^\perp)^{-1} X_2^{\perp \top} \mathbf{y}$  为  $\boldsymbol{\beta}_2$  的LS估计。

证明: 注意到  $\hat{\mathbf{y}} = P_{(\mathbf{1}, X_1, X_2)} \mathbf{y} = P_{(\mathbf{1}, X_1, X_2^\perp)} \mathbf{y} = \hat{\mathbf{y}}_0 + P_{X_2^\perp} \mathbf{y} = \hat{\mathbf{y}}_0 + X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp$

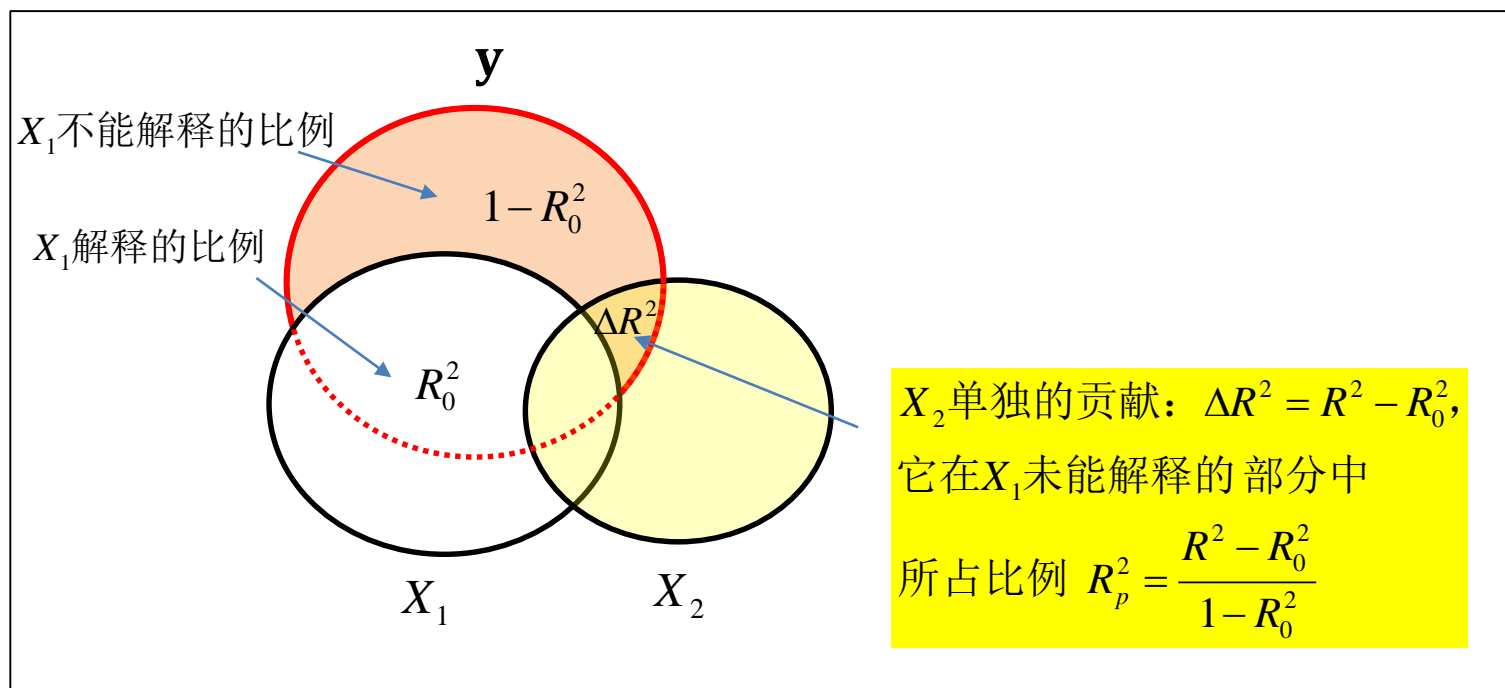
$\Rightarrow \hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp$ , 而  $\hat{\sigma}^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n-p)$ , 所以

$$F = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 / q}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n-p)} = \frac{\|X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp\|^2 / q}{\hat{\sigma}^2}$$

假设 $R^2$ 是全模型 $\mathbf{y}_{n \times 1} = \mathbf{X}_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}$ 下的决定系数， $R_0^2$ 是零模型下

的决定系数，前面我们对一般线性假设定义了 $R_p^2 = \frac{R^2 - R_0^2}{1 - R_0^2}$

代表 $\mathbf{y}$ 中 $X_1$ 不能解释的部分中， $X_2$ 所能解释的比例。命题6说明 $R_p^2$ 实际上是部分/偏决定系数（控制 $X_1$ 后， $\mathbf{y}$ 与 $X_2$ 之间的决定系数）。



命题6. 正态模型 $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}$ 中,  $X = (\mathbf{1}, X_1, X_2)$ ,  $\boldsymbol{\beta} = (\beta_0, \boldsymbol{\beta}_1^\top, \boldsymbol{\beta}_2^\top)$ ,

$$H_0 : \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1} \text{ 的F检验统计量 } F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2} \stackrel{H_0}{\sim} F_{q, n-p},$$

其中 $R_p^2 = \frac{S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}}{S_{yy \cdot 1}} \triangleq R_{yX_2 \cdot X_1}^2$  为控制 $X_1$ 时 $\mathbf{y}$ 与 $X_2$ 的部分 / 偏决定系数。

证明:  $\hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = X_2^\perp \hat{\boldsymbol{\beta}}_2 \Rightarrow$

$$\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \mathbf{y}^\top X_2^\perp (X_2^\perp{}^\top X_2^\perp)^{-1} X_2^\perp{}^\top \mathbf{y} = (n-1) S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1},$$

另外,  $\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \mathbf{1}\bar{y}\|^2 - \|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2$

$$= (n-1) S_{yy} - (n-1) S_{y1} S_{11}^{-1} S_{1y} = (n-1) S_{yy \cdot 1}$$

$$\text{所以 } R_p^2 = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2} = \frac{S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}}{S_{yy \cdot 1}}$$

R输出结果summary中包括了两种重要情形:

- 回归方程的显著性F检验: 检验所有自变量系数是否显著
- t检验: 检验单个回归系数是否显著

# 特例：回归方程的显著性检验和t检验

$$F = \frac{n-p}{p-1} \times \frac{R^2}{1-R^2} \stackrel{H_0: \mathbf{b} = \mathbf{0}}{\sim} F_{p-1, n-p}$$

回归方程的显著性检验：

假设模型  $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + Z\mathbf{b} + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ ,  $H_0: \mathbf{b} = \mathbf{0}$ ,

回归方程的显著性F检验：

$$F \stackrel{\text{命题5}}{=} \frac{\|Z_c \hat{\mathbf{b}}\|^2}{(p-1)\hat{\sigma}^2} \stackrel{\text{命题4}}{=} \frac{n-p}{p-1} \times \frac{R^2}{1-R^2} \sim_{H_0} F_{p-1, n-p}$$

$H_0$ 下模型为  $\mathbf{y} = \mathbf{1}\beta_0 + \boldsymbol{\varepsilon}$ ,  
决定系数  $R_0^2 = 1$

其中  $Z_c$  为  $Z$  的中心化,  $\hat{\mathbf{b}}$ ,  $\hat{\sigma}^2$  为LS估计,  $R^2$  为决定系数。

$F \geq F_{p-1, n-p}(1-\alpha)$  时在水平  $\alpha$  下否定原假设。

0

$$t = \text{估计值} \div \text{标准差} \sim t_{n-p}$$

单个变量的显著性检验:

假设模型  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \dots + \mathbf{x}_{p-1}\beta_{p-1} + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ ,

$$H_0 : \beta_k = 0, 1 \leq k \leq p-1$$

记  $\mathbf{x}_k^\perp = \mathbf{x}_k - P_{X_{(-k)}} \mathbf{x}_k$ ,  $X_{(-k)}$  为  $X$  除第  $k$  列之外的构成的矩阵, 记

$r_p = r_{yx_k}$  其它为  $y$  与  $x_k$  偏相关系数。  $H_0$  的  $F$  检验:

$$F \stackrel{\text{命题5}}{=} \frac{\|\mathbf{x}_k^\perp \hat{\boldsymbol{\beta}}_k\|^2}{\hat{\sigma}^2} \stackrel{\text{命题4}}{=} (n-p) \frac{r_p^2}{1-r_p^2} \stackrel{H_0}{\sim} F_{1, n-p}$$

$F$  检验等价于  $t$  检验

$$t = \pm \sqrt{F} = \frac{\hat{\beta}_k}{\hat{\sigma} / \|\mathbf{x}_k^\perp\|} = \sqrt{n-p} \frac{r_p}{\sqrt{1-r_p^2}} \sim_{H_0} t_{n-p} \quad \text{var}(\hat{\beta}_k | X) = \sigma^2 / \|\mathbf{x}_k^\perp\|^2$$



例2. 待遇上的性别歧视案例 (数据集salary: alr4). 有大学女教师反映女性在待遇上受到了歧视, 为此收集了一批数据, 包括每个大学教师的工资Salary, 性别Sex, 职称Rank和工龄Year。Salary~Sex得到Sex的效应是接近显著的(p=0.07), 但控制其它变量时Sex不再显著(p=0.46):

$$\text{Salary} = \beta_0 + \beta_1 \text{Sex} + \beta_2 \text{Rank} + \beta_3 \text{Year} + \varepsilon$$

lm(formula = Salary ~ Sex + Rank + Year, data = salary)

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	11011.76	966.95	11.388	3.03e-15 ***
<b>Sex</b>	<b>603.77</b>	<b>811.20</b>	<b>0.744</b>	<b>0.46</b>
Rank	4747.18	452.58	10.489	5.18e-14 ***
Year	393.86	74.53	5.285	3.04e-06 ***

---

Residual standard error: 2398 on 48 degrees of freedom  
 Multiple R-squared: 0.8454, Adjusted R-squared: 0.8358  
 F-statistic: 87.51 on 3 and 48 DF, p-value: < 2.2e-16

$t = \text{估计值} \div \text{标准差}$

$$t = 603.77 / 811.20 = 0.744$$

回归方程的显著性F检验

单个回归系数的t检验

在R软件中，summary没有输出的检验需要使用anova函数，比较完全模型和零模型

例如，同时检验Rank, Year的显著性： $H_0 : \beta_2 = \beta_3 = 0$ 。

```
> m1 = lm(Salary~Sex+Rank+Year, data=salary) #完全模型
> m0 = lm(Salary~Sex, data=salary) #零模型
> anova(m0, m1) #方差分析anova: 比较m0,m1
Analysis of Variance Table

Model 1: Salary ~ Sex
Model 2: Salary ~ Sex + Rank + Year
  Res.Df  RSS      Df Sum of Sq  F      Pr(>F)
1     50 1671623638
2     48 276016717  2  1395606921 121.35 < 2.2e-16 ***
```

$$F = \frac{n-p}{k} \times \frac{RSS_0 - RSS}{RSS} = \frac{52-4}{2} \times \frac{1671623638 - 276016717}{276016717} = 121.35$$


# 总结：F检验的构造及零分布

$$H_0: \theta = \theta_0 \text{ 的Wald 检验 } W = (\hat{\theta} - \theta_0)^T [\widehat{\text{var}}(\hat{\theta})]^{-1} (\hat{\theta} - \theta_0)$$

$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$ , 线性假设  $H_0: A\boldsymbol{\beta} = \mathbf{0}_{q \times 1}$ , F检验构造如下:

- Wald 检验:  $W = (A\hat{\boldsymbol{\beta}})^T [\widehat{\text{var}}(A\hat{\boldsymbol{\beta}})]^{-1} (A\hat{\boldsymbol{\beta}})$
- F检验:  $F = W/q$
- 由约束最小二乘结果, 以投影表示F

$$F = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}, \quad \hat{\mathbf{y}} = P_V \mathbf{y}, \quad \hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y}$$



其中  $V = C(X)$  和  $V_0$  分别为全模型下和原假设的自变量空间。

- $H_0$  成立时,  $F \sim F_{q, n-p}$ 。
- F的其它表示:  $F = \frac{n-p}{q} \times \frac{RSS_0 - RSS}{RSS} = \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R^2} = \frac{n-p}{q} \times \frac{R_p^2}{1 - R_p^2}$ ,  
即F检验比较全模型和原假设下的残差平方和或比较决定系数,  
 $R_p^2 = \frac{R^2 - R_0^2}{1 - R_0^2}$  为部分决定系数。

$F$ 检验所有表示形式，都是对比全模型和零模型下的拟合的差异

$$H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$$

$$F = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2} \quad \text{几何解释}$$

$$F = \frac{n-p}{q} \times \frac{RSS_0 - RSS}{RSS} \quad \text{几何解释, 软件使用}$$

$$F = \frac{\|X_2^\perp \hat{\boldsymbol{\beta}}_2\|^2}{q\hat{\sigma}^2} \quad \text{直观}$$

统一形式

$$F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2}$$

•  $q=1$ 情形:

$$p=2, q=1: \text{两个变量的相关性, } F = t^2 = (n-2) \frac{r^2}{1-r^2} \stackrel{H_0}{\sim} F_{1, n-2}$$

$$p > 2, q=1: \text{两个变量的偏相关性, } F = t^2 = (n-p) \frac{r_p^2}{1-r_p^2} \stackrel{H_0}{\sim} F_{1, n-p}$$

•  $q > 1$ 情形:

$$q = p-1: \text{回归方程的显著性, } F = \frac{n-p}{q} \times \frac{R^2}{1-R^2} \stackrel{H_0}{\sim} F_{p-1, n-p}$$

$$1 < q < p-1: F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2}$$

# 单因素方差分析 (one-way anova)

ANOVA: Analysis of variance

方差分析检验多个正态总体均值相等，是试验设计的重要分析方法。方差分析是线性回归模型中所有自变量为因子变量的特殊情形。

随机化控制试验中，研究对象被随机分配接受 $K$ 种处理(*treatment*)中的一种（比如 $K$ 种药物剂量），测量响应，假设各个组的响应服从方差相同但均值可能不同的正态分布，检验各组均值相等，称为单因素方差分析。

处理	$N(\mu_1, \sigma^2)$	...	$N(\mu_K, \sigma^2)$
响应	$y_{11}, y_{12}, \dots, y_{1n_1}$	...	$y_{K1}, y_{K2}, \dots, y_{Kn_K}$
平均	$\bar{y}_{1\cdot}$	...	$\bar{y}_{K\cdot}$

$$\bar{y}_{k\cdot} = \sum_{i=1}^{n_k} y_{ki} / n_k,$$
$$\bar{y}_{\cdot\cdot} = \left( \sum_{k=1}^K \sum_{i=1}^{n_k} y_{ki} \right) / n,$$

ANOVA  
模型

单因素方差法分析模型（双下标形式）：

$$y_{ki} = \mu_k + \varepsilon_{ki}, \quad \varepsilon_{ki} \text{ iid } \sim N(0, \sigma^2), \quad i = 1, \dots, n_k; k = 1, \dots, K.$$

$H_0: \mu_1 = \dots = \mu_K$ , 写成通常的线性模型形式：

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{g}_1\mu_1 + \dots + \mathbf{g}_K\mu_K + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 I_n),$$

其中 $\mathbf{g}_1, \dots, \mathbf{g}_K$ 为各组的示性表示， $X = (\mathbf{g}_1, \dots, \mathbf{g}_K)$ . 具体如下：

$$\begin{array}{l}
 \text{第一组} \\
 \vdots \\
 \text{第二组} \\
 \vdots \\
 \text{第 } K \text{ 组}
 \end{array}
 \begin{pmatrix}
 y_{11} \\
 \vdots \\
 y_{1n_1} \\
 y_{21} \\
 \vdots \\
 y_{2n_2} \\
 \vdots \\
 y_{K1} \\
 \vdots \\
 y_{Kn_K}
 \end{pmatrix}
 =
 \begin{pmatrix}
 1 & 0 & \dots & 0 \\
 \vdots & \vdots & \dots & 0 \\
 1 & 0 & \dots & 0 \\
 0 & 1 & \dots & 0 \\
 \vdots & \vdots & \dots & 0 \\
 0 & 1 & \dots & 0 \\
 \vdots & \vdots & \ddots & \vdots \\
 0 & 0 & 0 & 1 \\
 \vdots & \vdots & \vdots & \vdots \\
 0 & 0 & 0 & 1
 \end{pmatrix}
 \begin{pmatrix}
 \mu_1 \\
 \mu_2 \\
 \vdots \\
 \mu_K
 \end{pmatrix}
 +
 \begin{pmatrix}
 \varepsilon_{11} \\
 \vdots \\
 \varepsilon_{1n_1} \\
 \varepsilon_{21} \\
 \vdots \\
 \varepsilon_{2n_2} \\
 \vdots \\
 \varepsilon_{K1} \\
 \vdots \\
 \varepsilon_{Kn_K}
 \end{pmatrix}
 =
 \begin{pmatrix}
 \mathbf{1}_{n_1} & \mathbf{0} & \dots & \mathbf{0} \\
 \mathbf{0} & \mathbf{1}_{n_2} & \dots & \mathbf{0} \\
 \vdots & \vdots & \dots & \vdots \\
 \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_{n_K}
 \end{pmatrix}
 \begin{pmatrix}
 \mu_1 \\
 \mu_2 \\
 \vdots \\
 \mu_K
 \end{pmatrix}
 + \boldsymbol{\varepsilon},$$

$$(\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_K)$$

下面求  $H_0: \mu_1 = \dots = \mu_K$  的  $F$  检验:  $F = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 / q}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n - p)}$ ,  $p = K, q = K - 1$

$$\hat{\mathbf{y}} = P_{\mathbf{g}_1} \mathbf{y} + \dots + P_{\mathbf{g}_K} \mathbf{y} = \mathbf{g}_1 \bar{y}_{1\bullet} + \dots + \mathbf{g}_K \bar{y}_{K\bullet} = (\bar{y}_{1\bullet}, \dots, \bar{y}_{1\bullet}, \bar{y}_{2\bullet}, \dots, \bar{y}_{2\bullet}, \dots, \bar{y}_{K\bullet}, \dots, \bar{y}_{K\bullet})^\top$$

$H_0$  下模型为:  $\mathbf{y} = (\mathbf{g}_1 + \dots + \mathbf{g}_K) \mu_1 + \boldsymbol{\varepsilon} = \mathbf{1} \mu_1 + \boldsymbol{\varepsilon}$ ,  $V_0 = L(\mathbf{1})$ .

$$\hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y} = (\bar{y}_{\bullet\bullet}, \dots, \bar{y}_{\bullet\bullet})^\top = \mathbf{1} \bar{y}_{\bullet\bullet}$$

容易验证  $F = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 / q}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n - p)} = \frac{SS_B / (K - 1)}{SS_W / (n - K)}$  (下页)

命题7. 单因素方差分析, 零假设 $H_0: \mu_1 = \dots = \mu_K$ 的F检验

$$F = \frac{SS_B / (K - 1)}{SS_W / (n - K)} \sim_{H_0} F_{K-1, n-K}$$

- $SS_B = \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \sum_{k=1}^K \sum_{i=1}^{n_k} (\bar{y}_{k\cdot} - \bar{y}_{\cdot\cdot})^2$

组间平方和(回归平方和), 度量了各组的中心  $\bar{y}_{k\cdot}, k = 1, \dots, K$  之间的差异。

- $SS_W = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \sum_{k=1}^K \sum_{i=1}^{n_k} (y_{ki} - \bar{y}_{k\cdot})^2,$

组内平方和(残差平方和), 度量了组内样本的差异。

- $SS_{\text{总}} = SS_B + SS_W, \quad \text{B: Between - group, W: Within - group}$

注:  $F$  的主要部分  $SS_B$  度量了  $K$  个中心的差异 ( $SS_W$  仅用来标准化)。


特别地, 当  $K = 2$  (两正态),  $F = t^2, t \sim_{H_0} t_{n-2}$ .

```
R命令: > aov(响应 ~ 组别, data =... )
> lm(响应 ~ 组别, data =... )
```

# 两因素方差分析

## 随机区组设计 (Randomized block design)

随机化试验设计中，当研究对象差异较大时，为了避免处理组与对照组出现严重的不均衡，通常先将研究对象分成内部个体相似的区组或层(blocks/strata)，在区组内随机化分配处理。关心的问题是各个处理是否存在差异。决定分组的因素/因子有两个：处理和区组。假设两个因子各有 $I, J$ 个水平，交叉分类得到 $I \times J$ 表，只考虑格子内只有一次测量的情形



模型:  $y_{ij} \sim N(\mu_{ij}, \sigma^2)$ , 假设可加模型:  $\mu_{ij} = \mu + \alpha_i + \beta_j$ , 或

$$y_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij}, \quad \varepsilon_{ij} \sim N(0, \sigma^2)$$



## 两因素方差分析F检验

命题8.  $I$ 个处理水平,  $J$ 个区组, 假设 $(i, j)$ 水平下的测量 $y_{ij}$ 满足可加模型

$$y_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij}, \quad \varepsilon_{ij} \text{ iid} \sim N(0, \sigma^2), \quad (\alpha's \text{ 和 } \beta's \text{ 各有一个约束})$$

$H_0: \alpha_1 = \dots = \alpha_I = 0$  的  $F$  检验为:

$$F = \frac{SS_{\text{处理}} / (I - 1)}{SS_{\text{组内}} / (I - 1)(J - 1)} \stackrel{H_0}{\sim} F_{I-1, (I-1)(J-1)}$$

- $SS_{\text{处理}} = \sum_{i=1}^I \sum_{j=1}^J (\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot})^2$ ,  $K$ 个处理之间的差异
- $SS_{\text{组内}} = \sum_{i=1}^I \sum_{j=1}^J (y_{ij} - \bar{y}_{i\cdot} - \bar{y}_{\cdot j} + \bar{y}_{\cdot\cdot})^2$ , 残差平方和

$$\text{行平均 } \bar{y}_{i\cdot} = \sum_{j=1}^J y_{ij} / J,$$

$$\text{列平均 } \bar{y}_{\cdot j} = \sum_{i=1}^I y_{ij} / I,$$

$$\text{总平均 } \bar{y}_{\cdot\cdot} = \sum_{j=1}^J \sum_{i=1}^I y_{ij} / IJ$$

Key:  $\mu_{ij} = \mu + \alpha_i + \beta_j$  表明  $\mu_{ij} - \mu_{i'j} = \alpha_i - \alpha_{i'}$  不依赖于区组  $j$ , 即两个处理  $i, i'$  的差异在各个区组内相同, 因此处理平方和与区组效应  $\beta's$  无关:

$$SS_{\text{处理}} = \sum_{i=1}^I \sum_{j=1}^J (\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot})^2 = J \sum_{i=1}^I (\alpha_i - \bar{\alpha} + \bar{\varepsilon}_{i\cdot} - \bar{\varepsilon}_{\cdot\cdot})^2$$

$\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot}$  代表了处理  $i$  的效应, 要点在于不同区组的响应可以累加  $\bar{y}_{i\cdot}$ , 但其中包含的累加的区组效应与  $\bar{y}_{\cdot\cdot}$  中包含的区组效应抵消了。列联表分析中类似的思想可得 Cochran - Mantel - Haenszel 检验。

# 配对t检验

## 配对设计

配对设计(paired design): 两个相像的研究对象（比如双胞胎），随机选取其中一人服用药物（处理），另一个服用安慰剂（对照）。

pair	1	2	...	$J$	平均
对照	$y_{11}$	$y_{12}$	...	$y_{1J}$	$\bar{y}_{1\cdot}$
处理	$y_{21}$	$y_{22}$	...	$y_{2J}$	$\bar{y}_{2\cdot}$
差	$z_1$	$z_2$	...	$z_J$	$\bar{z}$

第 $j$ 对样本组成一个区组，响应： $(y_{1j}, y_{2j})$ ，下标2表示处理,1表示对照。

假设两因素方差分析模型

$$y_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij}, \varepsilon_{ij} \sim N(0, \sigma^2), i = 1, 2; j = 1, \dots, J$$

其中 $\alpha_1 = 0$ ， $\alpha_2$ 代表药效。

配对设计是最简单的区组设计，每一个pair就是一个区组。区组内的两个研究对象相似，但接受不同的处理。可以验证命题8当 $I = 2$ 时， $F = (t_{pair})^2$ ， $t_{pair}$ 具有如下形式

成对t检验  
(paired t-  
test/depend  
ent t-test)

命题9. 配对样本 $(y_{1i}, y_{2i})$ ,  $i = 1, \dots, n$  iid, 令 $z_i = y_{2i} - y_{1i}$ ,  $\alpha_2 = E(z_i)$ ,  $H_0: \alpha_2 = 0$ 的成对t检验

$$t_{\text{pair}} = \frac{\bar{z}}{s_z/\sqrt{n}} = \frac{(\bar{y}_{2\cdot} - \bar{y}_{1\cdot})}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_{2i} - y_{1i} - (\bar{y}_{2\cdot} - \bar{y}_{1\cdot}))^2/n}} \stackrel{H_0}{\sim} t_{n-1}$$

同一个pair内的两个个体相似(匹配、相依), 将它们作为独立样本进行两样本t检验是错误的做法.

# 置信域和同时置信区间

Tukey's quote: *Far better an approximate answer to the right question, which is often vague (同时置信区间), than an exact answer to the wrong question, which can always be made precise (置信域).*

回归系数  
的置信域

正态线性模型  $\mathbf{y}_{n \times 1} = \mathbf{X}_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}_{n \times 1}$ ,  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 \mathbf{I}_n)$

由定理2, 对任何行满秩  $q \times p$  常数矩阵  $A = (\mathbf{a}_1, \dots, \mathbf{a}_q)^\top$ ,

$$\frac{(\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta})^\top (\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top)^{-1} (\mathbf{A}\hat{\boldsymbol{\beta}} - \mathbf{A}\boldsymbol{\beta})}{q\hat{\sigma}^2} \sim F_{q, n-p},$$

称为枢轴量 (分布与参数无关), 基于此我们构建置信域:

$\boldsymbol{\theta} = \mathbf{A}\boldsymbol{\beta}$  的 (即  $q$  个参数  $\theta_1 = \mathbf{a}_1^\top \boldsymbol{\beta}, \dots, \theta_q = \mathbf{a}_q^\top \boldsymbol{\beta}$  的) 置信度为  $1 - \alpha$  的置信椭球

$$C = \left\{ \boldsymbol{\theta} \in R^q: \frac{(\boldsymbol{\theta} - \mathbf{A}\hat{\boldsymbol{\beta}})^\top [\mathbf{A}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{A}^\top]^{-1} (\boldsymbol{\theta} - \mathbf{A}\hat{\boldsymbol{\beta}})}{q\hat{\sigma}^2} \leq F_{q, n-p}(1 - \alpha) \right\},$$

注意  $C$  是  $R^q$  中的椭球区域,  $P(C) = 1 - \alpha$ 。

注：当参数个数为 $q = 1$ 的时候，上述置信椭球为通常的置信区间：

- 若 $A = \mathbf{a}^\top$  (行向量),  $\mathbf{a}^\top \boldsymbol{\beta}$ 的 $(1 - \alpha)100\%$ 置信区间：

$$\left\{ \mathbf{a}^\top \boldsymbol{\beta} : |\mathbf{a}^\top \boldsymbol{\beta} - \mathbf{a}^\top \hat{\boldsymbol{\beta}}| \leq t_{n-p}(\alpha/2) \hat{\sigma} \sqrt{\mathbf{a}^\top (X^\top X)^{-1} \mathbf{a}} \right\}$$

- 若 $A = (0, \dots, 1, \dots, 0)^\top$ 时,  $\beta_k$ 的置信区间：

$$\left\{ \beta_k : |\beta_k - \hat{\beta}_k| \leq t_{n-p}(\alpha/2) \hat{\sigma} / \|\mathbf{x}_k^\perp\| \right\}$$


参数 $\theta_1 = \mathbf{a}_1^\top \boldsymbol{\beta}, \dots, \theta_q = \mathbf{a}_q^\top \boldsymbol{\beta}$ 的置信椭球不容易理解和解释，能否构建 $q$ 个参数的方型置信域，称为同时置信区间(simultaneous confidence interval)?

$$\left\{ (\theta_1, \dots, \theta_q)^\top : L_j \leq \theta_j \leq U_j, j = 1, \dots, q, (L_j + U_j) / 2 = \hat{\theta}_j = \mathbf{a}_j^\top \hat{\boldsymbol{\beta}} \right\}$$

由 $q$ 个区间构成： $\otimes \{\theta_j : L_j \leq \theta_j \leq U_j\}$ ，容易解释和应用。。

可以想象，每个边际区间都要比只考虑一个参数的时候稍长，我们希望同时置信区间覆盖参数 $\theta_1, \dots, \theta_q$ 的概率等于给定的置信水平 $1-\alpha$ ，但实际上即使在联合正态假设下这也难以做到，我们只能粗略地控制覆盖概率不低于置信水平 $1-\alpha$  (即偏保守)。

置信椭圆 “wrong” question, accurate answer



常见的方法有：**Bonferroni**同时置信区间,**Sheffe**同时置信区间,方差分析模型的**Tukey**同时置信区间。

## Bonferroni 不等式

$$\text{Bonferroni 不等式: } P\left(\bigcup_{j=1}^q E_j\right) \leq \sum_{j=1}^q P(E_j)$$

假设参数  $\theta_j$  的置信区间为  $E_j, \theta_1, \dots, \theta_q$  的同时置信区间为  $\bigcap E_j$ , 我们希望

$$P\left(\bigcap_{j=1}^q E_j\right) \geq 1 - \alpha \quad (\text{给定的置信水平})$$

假设每个区间覆盖真参数的概率为  $1 - \gamma$ , 即  $P(E_j) = 1 - \gamma$ , 由 Bonferroni 不等式

$$P\left(\bigcap_{j=1}^q E_j\right) = 1 - P\left(\bigcup_{j=1}^q \bar{E}_j\right) \geq 1 - \sum P(\bar{E}_j) = 1 - q\gamma$$

取  $\gamma = \alpha / q$ , 即每个区间  $E_j$  的置信度取  $1 - \alpha / q$  即可保证  $\bigcap E_j$  的覆盖率不小于  $1 - \alpha$ .

若  $E_j$  独立, 则  $P\left(\bigcap E_j\right) = \prod P(E_j) = (1 - \alpha / q)^q \approx 1 - q\alpha$ , 此时 Bonferroni 不等式几乎是等式, 即 Bonferroni 不等式 / 置信区间几乎是不可改进的。

## Bonferroni 同时置信区间

$A\beta$  的 Bonferroni 同时置信区间:

$$\bigcap_{j=1}^q E_j = \bigcap_{j=1}^q \left\{ \mathbf{a}_j^\top \boldsymbol{\beta}: |\mathbf{a}_j^\top \boldsymbol{\beta} - \mathbf{a}_j^\top \hat{\boldsymbol{\beta}}| \leq t_{n-p} \left( \frac{\alpha}{2q} \right) \hat{\sigma} \sqrt{\mathbf{a}_j^\top (X^\top X)^{-1} \mathbf{a}_j} \right\}$$

称为是  $\mathbf{a}_1^\top \boldsymbol{\beta}, \dots, \mathbf{a}_q^\top \boldsymbol{\beta}$  的置信度为  $1 - \alpha$  的 Bonferroni 同时置信区间

每个置信区间的置信度为  $1 - \frac{\alpha}{q} > 1 - \alpha$ ,

比置信度  $1 - \alpha$  的区间稍宽

## 多重检验

多重假设检验(multiple testing)同时检验 $q$ 个零假设（对应于同时置信区间），每次检验的错误率假设为 $\beta$ ，多次检验发生错误的概率会增加（inflation of type I error rate）。我们希望所有零假设成立的时候，否定至少一个零假设的概率(即I型错误率)不大于给定的水平 $\alpha$ 。最常用的方法是Bonferroni校正,即每个假设检验的水平选取为 $\beta = \alpha / q$ .

## 应用/动机: 事后分析

事后分析(post-hoc analysis):

- 单因素方差分析检验 $\mu_1 = \dots = \mu_g$ ，F检验称为omnibus检验(一揽子检验)
- 如果结果显著，我们希望发现到底是哪些组之间不同，即事后分析
- 事后分析需要给出 $g(g-1)/2$ 个差别 $\mu_i - \mu_j, 1 \leq i < j \leq g$ 的同时置信区间，或等价地检验 $g(g-1)/2$ 个原假设 $H_0^{(ij)}: \mu_i = \mu_j, 1 \leq i < j \leq g$ .
- 显然各个检验/区间不独立，Bonferroni方法过于保守，Tukey提出了一种基于学生化极差分布的同时置信区间。

## 应用:全基因组关联分析

全基因组数十万、百万个基因，哪些与疾病关联？

不可能同时检验，通常逐个检验每个基因与疾病的关联性，这是多重检验，需要控制一型错误率。